# Expansión de consultas utilizando recursos lingüísticos para mejorar la recuperación de información

**Mg. Claudia Deco**
Departamento de Sistemas e Informática
Facultad de Ciencias Exactas, Ingeniería y Agrimensura
Universidad Nacional de Rosario

Rosario, Argentina

# Recuperación de Información - 1

Buscar material en bibliotecas ó centros de información

- Fichero manual
- Catálogo informatizado de cada biblioteca

- **Especialista**: encargado de expresar la necesidad de información del usuario mediante una estrategia de búsqueda

- Problemas

  **Tiempo** elevado de **búsqueda** (ir de biblioteca en biblioteca)

  **Información desactualizada** e **insuficiente**

# Recuperación de Información - 2

## Búsqueda actual

- Catálogo online de cada biblioteca
- Bancos de datos remotos online

Continúa presente el especialista en ciencias de la información

- Internet
  - Acceso a bases de datos
  - Páginas web
  - Buscadores (Altavista, Yahoo, Google, ... )

- Problemas

  **Ausencia** del especialista
  **Información** en **exceso**
  **Tiempo elevado** de **búsqueda**

# Recuperación de Información - 3

## Tarea típica de la RI

Dados:

- Un **corpus** de documentos textuales en lenguaje natural.
- Una **consulta** de usuario en la forma de un string de texto.

Encontrar:

- datos con la **mejor coincidencia** con el patrón dado
- **ordenados** según su **relevancia** para la consulta

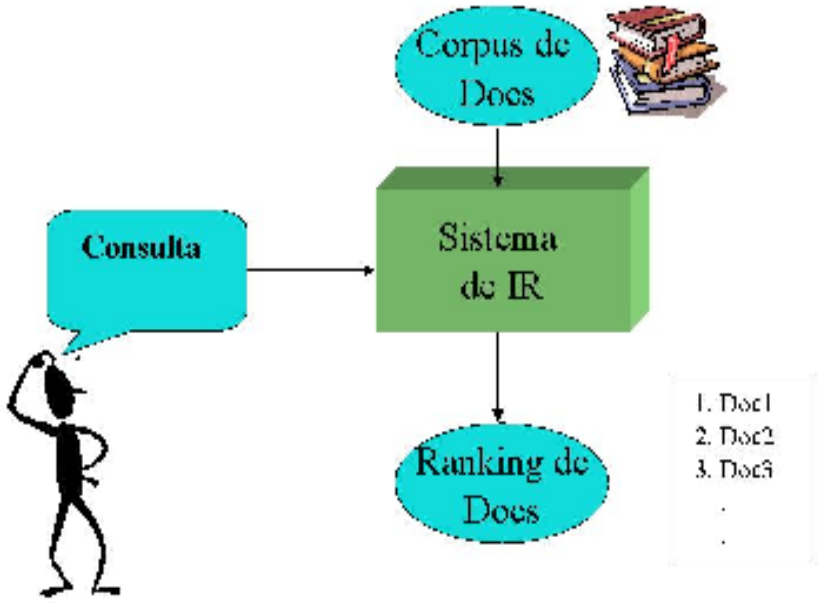

# Problemas

- Encontrar **información útil** en la **Web** es frecuentemente una **tarea difícil**.

- **Problemas** para la búsqueda en la web.
  - con los **datos**.
  - con los **usuarios**.

# Problemas

## Problemas con los datos

- **Datos distribuidos**.
- **Datos volátiles.** (dinámica de Internet)
- **Gran volumen.** (crecimiento exponencial de la Web).
- **Datos no estructurados y redundantes** (30% duplicado).
- **Calidad de los datos.** (no hay proceso ni control editorial)
- **Datos heterogéneos.** (estructural, semántica)

## Problemas con los usuarios

- **Cómo especificar la consulta**
- Cómo interpretar las respuestas obtenidas

# Algunas estadísticas

- promedio de **palabras por consulta**: 2 palabras
- **operadores lógicos por consulta**: 0,4.
- el 80% de los usuarios **no modifica su consulta inicial**
- el 85% **ve sólo la primera página** de la respuesta.
- el 85% de los usuarios **utiliza motores de búsqueda**
- los usuarios **no están conformes** con los resultados obtenidos

# Algunas estadísticas

Esto indicaría

- la mayoría de los **usuarios desconoce técnicas de RI**
- tiene **dificultad de expresar claramente** su necesidad de información

$\Rightarrow$ **no obtienen los resultados deseados**.

# Ejemplo Motivador

"*Utilización de la aspirina en el cáncer*"

Nuestro enfoque es
la expansión de los conceptos involucrados:

{ aspirina, cáncer }

- Dominio: Cáncer: ¿medicina? ¿horóscopo? ¿astrología? ...
- Especificidad: ¿Interesa todo tipo de cáncer ó algún tipo particular?
- Equivalencias semánticas: Existen sinónimos de cáncer que pueden no recuperarse, por ejemplo neoplasma.

# Expansión de consultas

- es el proceso de suplementar la consulta original con términos adicionales.
- es un método para mejorar la recuperación.
- puede ser desarrollada manual, automática o interactivamente.

Se propone una **expansión de la consulta semiautomática**:

El sistema sugiere términos

y es el usuario quien decide cuál ó cuáles

representan su interés de búsqueda.

# Contexto

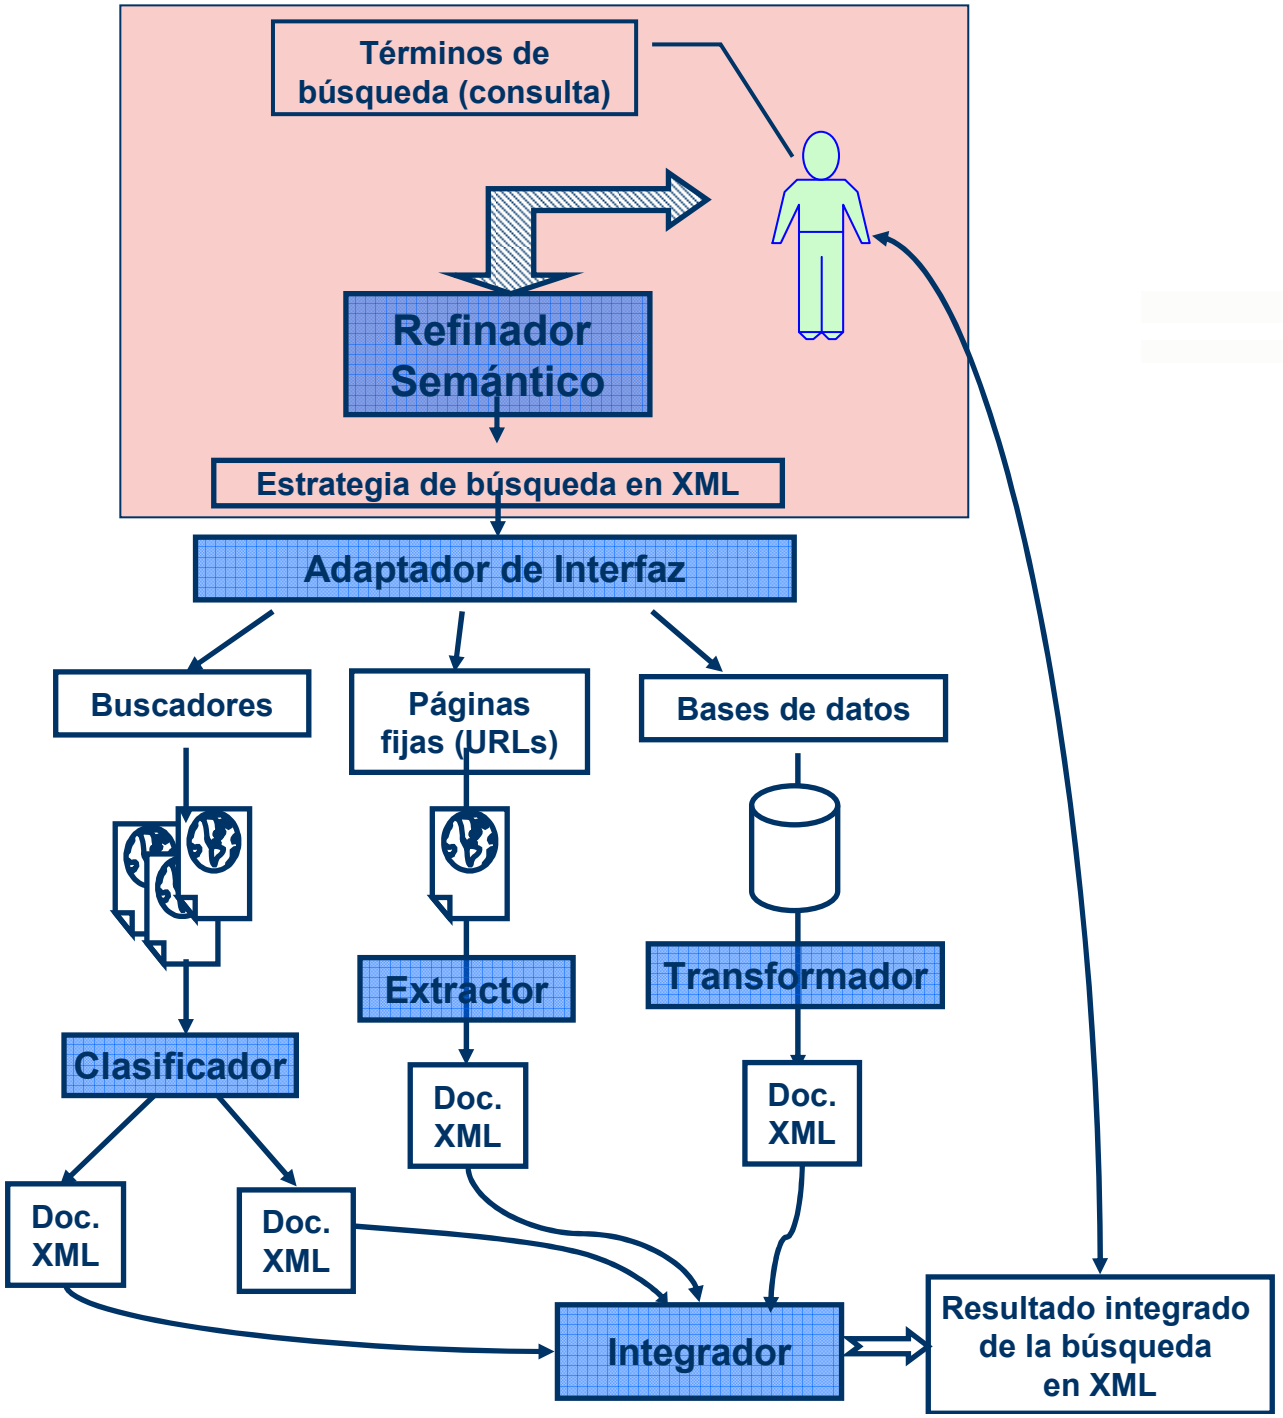
Términos de búsqueda (consulta)
Refinador Semántico
Estrategia de búsqueda en XML
Adaptador de Interfaz
Buscadores
Páginas fijas (URLs)
Bases de datos
Extractor
Transformador
Clasificador
Doc. XML
Doc. XML
Doc. XML
Doc. XML
Integrador
Resultado integrado de la búsqueda en XML

# Refinamiento Semántico para Recuperación de Información desde la Web

Que le permita al usuario

- **Desambiguar** sentidos de los conceptos
- **Seleccionar** conceptos jerárquicamente relacionados
- **Expandir** semánticamente cada concepto

para preparar una Estrategia de Búsqueda adecuada a su necesidad de información

# Estrategia de Búsqueda

Es una **expresión lógica** compuesta por distintos conceptos combinados con conectores lógicos AND, OR y NOT.

- Indicadores para evaluar:

$$\text{Precisión} = \frac{\text{Número de documentos relevantes recuperados}}{\text{Número de documentos recuperados}}$$

$$\text{Recall} = \frac{\text{Número de documentos relevantes recuperados}}{\text{Número total de documentos relevantes}}$$

Realizada una búsqueda:

el conj. de docs recuperados **no coincide** totalmente con el conj. de docs relevantes sobre el tema de interés.

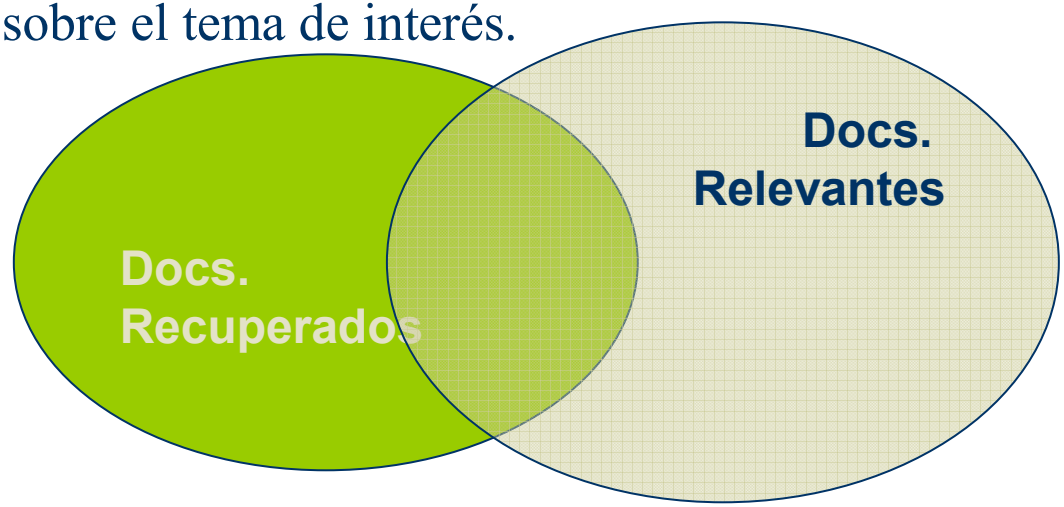


Una **búsqueda** será **óptima** cuando estos **dos conjs. coincidan**

→ todos los docs recuperados sean relevantes
y todos los docs relevantes sean recuperados.

# Estrategia de Búsqueda

En su preparación pueden ocurrir contingencias debido a:

- el uso de términos **ambiguos** o no específicos
- la utilización de términos **demasiado específicos**,
- la **falta** de conceptos
- el uso incorrecto de la disyunción (**OR**) y la conjunción (**AND**)
- el uso incorrecto de la negación (**NOT**)
- el uso incorrecto de **paréntesis**
- **no** incluir **sinónimos** suficientes,
- errores de tecleo,
- errores de deletreo (“color” y “colour”),

# Recursos lingüísticos que se utilizan en la RI

- Diccionarios
- Diccionarios multilinguales
- Ontologías
- Tesauros

# Recursos lingüísticos que se utilizan en la RI

## Diccionarios

- Indican las **distintas acepciones** de un término
- Permiten su **expansión** con **sinónimos**
- y sugieren términos **relacionados jerárquica y/o semánticamente**

## Diccionarios multilinguales

- Permiten **traducir** un concepto a otros idiomas.

# Recursos lingüísticos que se utilizan en la RI

## Tesauros

- Permiten el control del vocabulario para **representar en forma unívoca** cada concepto.

- **Términos relacionados** semántica y genéricamente, los cuales cubren un **dominio específico** del conocimiento.

- **Interrelaciones**: jerárquicas, de afinidad y preferenciales (sinónimos – homónimos)

# Recursos lingüísticos que se utilizan en la RI

## Ontologías

- Permiten representar el conocimiento en la web.
- Definen conceptos y relaciones de algún dominio.
- Consisten de términos, sus definiciones y axiomas.
  - Los axiomas permiten **inferir conocimiento** que no esté indicado explícitamente en la taxonomía de conceptos.

# Ejemplos

**WordNet** (www.cogsci.princeton.edu/~wn/ )

- Es un **sistema de referencia léxica** online
  - incluye sinónimos, variantes de deletreo, ampliación de siglas, y para ciertos términos su escritura en otros idiomas.
  - tiene relaciones jerárquicas: muestra para cada término
    - sus términos específicos ó hipónimos, y
    - su término más amplio ó hiperónimo.

# WordNet

**Results for Hyponyms of noun "cancer"**

Sense 1
cancer, malignant neoplastic disease --
(any malignant growth or tumor caused by abnormal and uncontrolled cell di vision; it may spread to other parts of the body through the lymphatic system or the blood stream)

=> lymphoma --
(a neoplasm of lymph tissue that is usually malignant; one of the four major t ypes of cancer)

=> carcinoma --
(any malignant tumor derived from epithelial tissue; one of the four major typ es of cancer)
=> liver cancer, cancer of the liver --
(malignant neoplastic disease of the liver usually occurring as a metastasis f rom another cancer; symptoms include loss of appetite and weakness and bl oating and jaundice and upper abdominal discomfort)

=> adenocarcinoma, glandular cancer, glandular carcinoma --
(malignant tumor originating in glandular epithelium)
=> prostate cancer, prostatic adenocarcinoma --
(cancer of the prostate gland)

=> breast cancer --
(cancer of the breast; one of the most common malignancies in women )
.....

# MeSH

**"lung cancer"** is not a MeSH term, but it is associated with the MeSH term **Lung Neoplasms**

**Lung Neoplasms** : Tumors or cancer of the LUNG.

Term **Lung Neoplasms** appears in more than one place in the MeSH tree.

All MeSH Categories
- Diseases Category
  - Neoplasms
    - Neoplasms by Site
      - Thoracic Neoplasms
        - Respiratory Tract Neoplasms
          - **Lung Neoplasms**
            - Carcinoma, Bronchogenic
            - Coin Lesion, Pulmonary
            - Pancoast's Syndrome
            - Pulmonary Blastoma

# ¿Qué diferencia hay entre estos recursos?

- **Diccionario:** todos los sinónimos son representativos y tratados por igual.
- **Tesauro:** se tiene una **palabra clave** preferida y **representativa** del conjunto de sinónimos para cada concepto.
- **Ontologías:** se agregan los **axiomas**, que permiten realizar **inferencias sobre conceptos**.
- En **BD:** terminología está **controlada** y el uso de **tesauros** permite obtener un resultado más preciso.
- En **Web:** terminología **no** está **controlada**. Por esto el uso de **diccionarios** y de **ontologías** es más adecuado.

# Refinamiento semántico

Una búsqueda que involucra los conceptos

$$\{ C_1 , C_2 , \ldots , \text{not } C_h , \ldots , C_n \}$$

resulta en una estrategia de búsqueda.

# Arquitectura para la preparación de la Estrategia de Búsqueda

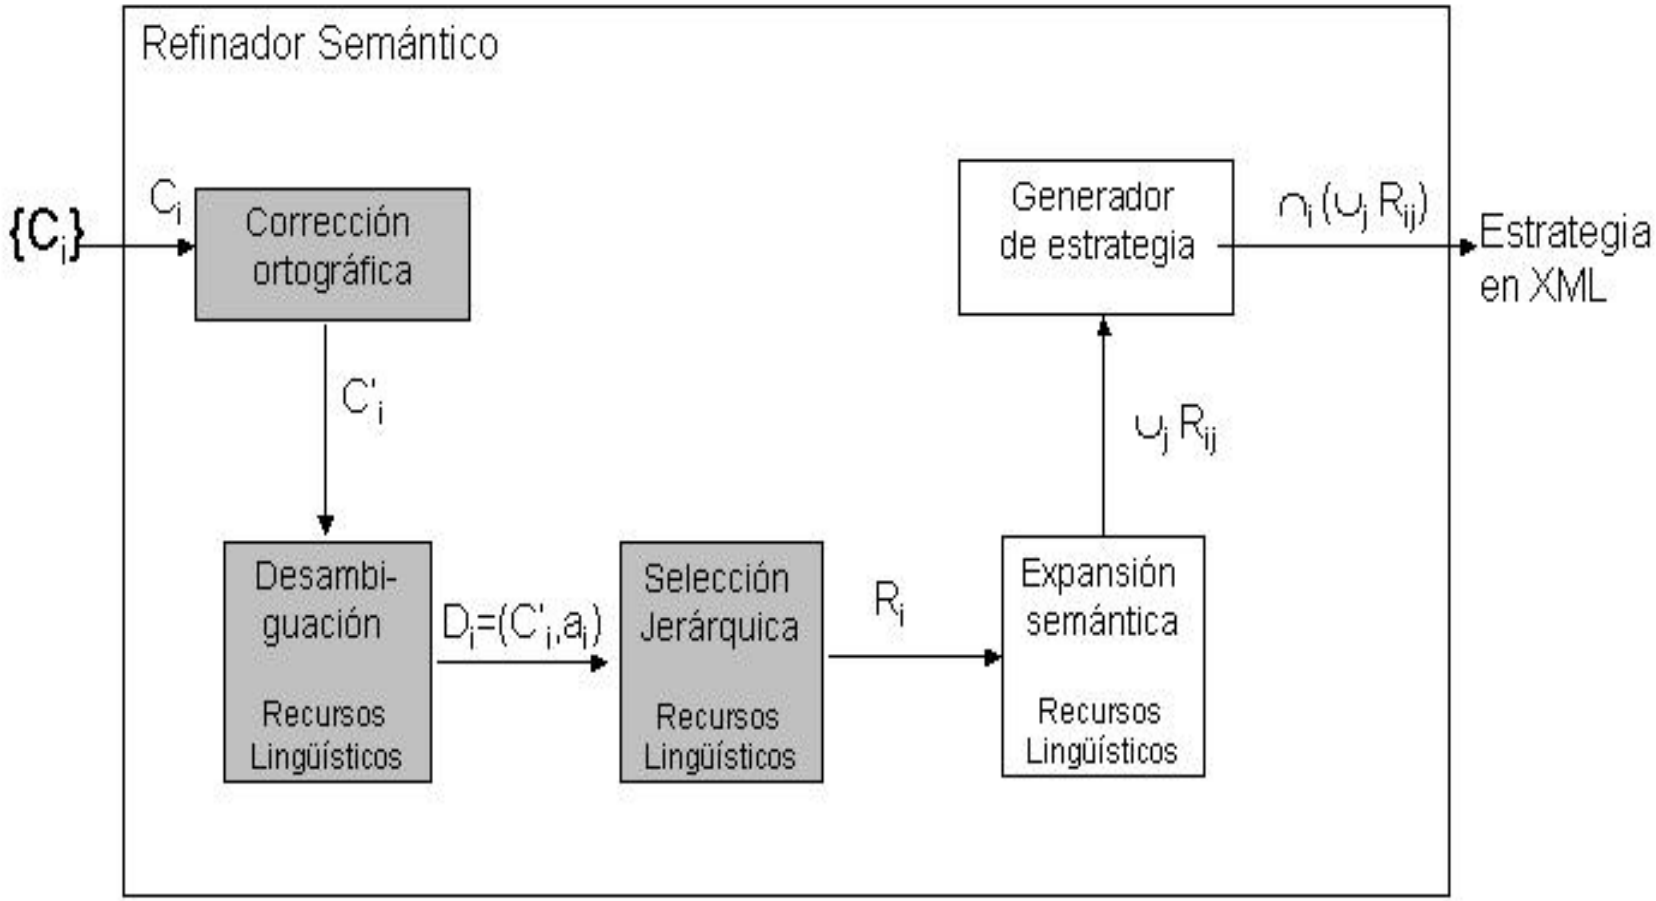

# Refinamiento semántico

- Se representa en XML.
  - Porque es el estándar de intercambio de datos
  - La estrategia es independiente de la sintaxis de los lenguajes de consulta a las fuentes.
    - Bases de datos, Páginas web, Buscadores

    Ventaja: el usuario no necesita conocer las distintas sintaxis de buscadores
- Un adaptador de interfaz transforma este XML a las sintaxis de las distintas fuentes.

# Ejemplo resuelto con el RS

Para la búsqueda que involucra los conceptos:

***cáncer de pulmón , aspirina , tratamiento***

Una estrategia sería

**(lung neoplasms OR lung cancer OR cáncer de pulmón OR carcinoma of the lungs)**

**AND**

**(aspirina OR aspirin OR ácido acetil salicílico)**

**AND**

**(tratamiento OR treatment)**

**dependerá de los RL utilizados**

y el XML será

```
<estrategia>
    <concepto 1>
        <ampliación 1>cáncer de pulmón</ampliación 1>
        <ampliación 2>lung cancer</ampliación 2>
        <ampliación 3>lung neoplasms</ampliación 3>
        <ampliación 4>carcinoma of the lungs </ampliación 4>
    </concepto 1>
    <concepto 2>
        <ampliación 1>aspirina</ampliación 1>
        <ampliación 2>aspirin</ampliación 2>
        <ampliación 3>ácido acetil salicílico</ampliación 3>
    </concepto 2>
    <concepto 3>
        <ampliación 1>tratamiento</ampliación 1>
        <ampliación 2>treatment</ampliación 2>
    </concepto 3>
</estrategia>
```

# Prototipos

- Utilización de
  - estándares y recomendaciones del grupo W3C y
  - lenguajes y recursos libres disponibles en la web
    - Selección de jerarquía y la expansión semántica: MeSH – **WordNet**
    - Lenguaje para implementar: PHP
    - Buscador: Google - **Yahoo**!

# Experimentación

- Se realizaron consultas.
- Niveles de usuarios:  Inexperto, Medio, Experto.

- Cada usuario describió su interés de búsqueda
- Cada usuario planteó la estrategia directamente a un buscador
- Se planteó la estrategia generada por el refinador semántico

- Se registró:
  - la cantidad de documentos resultantes, y
  - la cantidad de docs que respondían al interés del usuario en los primeros 50 docs. $\Rightarrow$ *precisión*

| | | | | | | | |
|---|---|---|---|---|---|---|---|
| Karting Race | 431.000 | 21 | - Karting Race | “Karting Race” | 3.660 | 26 | Inexperto |
| Oedipus Complex | 87.900 | 22 | - Oedipus Complex | “Oedipus Complex” OR “Oedipal Complex” | 53.100 | 33 | Medio |
| bulimia treatment | 403.000 | 47 | - treatment<br>- bulimia | treatment AND (bulimia OR “binge-eating syndrome”) | 408.000 | 47 | Medio |
| software distributor usa | 941.000 | 23 | - software<br>- distributor<br>- usa | (software OR “software system” OR “software package” OR package) AND (distributor OR distributer) AND (usa OR “u.s.a.” OR us OR “u.s.” OR “United States of America” OR “United states”) | 2.250.000 | 21 | Medio |
| software distributor usa | 941.000 | 23 | - software<br>- distributor<br>- usa | (software OR “software system” OR “software package” OR package) AND (distributor OR distributer) AND (“United States of America” OR “United states”) | 1.520.000 | 25 | Medio |
| food without sugar | 2.680.000 | 13 | - food | “diabetic diet” | 89.800 | 19 | Inexperto |
| Yamaha virago model | 34.400 | 14 | - yamaha virago<br>- model | “yamaha virago” AND model | 7.800 | 48 | Inexperto |
| penicillin discovery | 76.200 | 7 | - penicillin<br>- discovery | penicillin AND (discovery OR find OR uncovering) | 78.900 | 7 | Medio |

# Algunos Resultados

- El usuario no utiliza la búsqueda por frases.

  Ejemplo: Gabriel García Márquez

El uso de frases

- **aumenta** la **precisión**, y
- **disminuye** la **cantidad** de docs recuperados.

- La corrección ortográfica realizada por el refinamiento
  - **aumenta** la cantidad de documentos recuperados y
  - **aumenta** la precisión.

Ejemplo: escherichia colli (12.000)

***escherichia coli*** (8.500.000)

# Resultados de la experimentación

**Consultas con términos más específicos**

*treatment* y *Hodgkin*

movimiento por jerarquía conceptual asociada

*lymphoma*

*"hodgkin's disease"*

- **disminuye** la **cantidad** de docs recuperados.
- **aumenta** la **precisión**.

# Cantidad de documentos resultantes con y sin refinamiento semántico en escala logarítmica

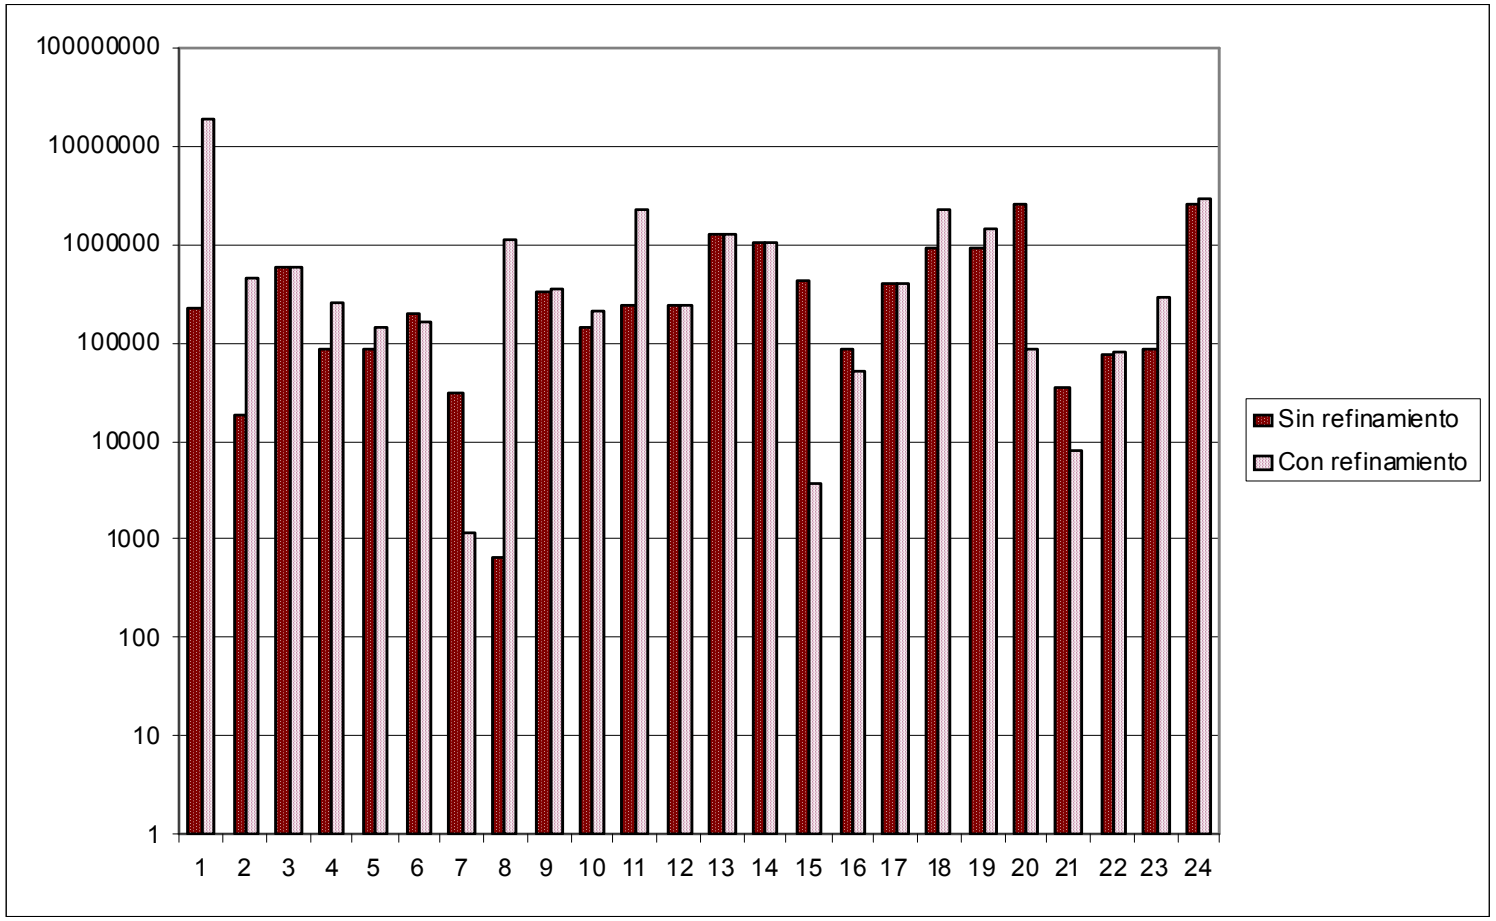

# Precisión en los primeros 50 documentos, con y sin refinamiento semántico

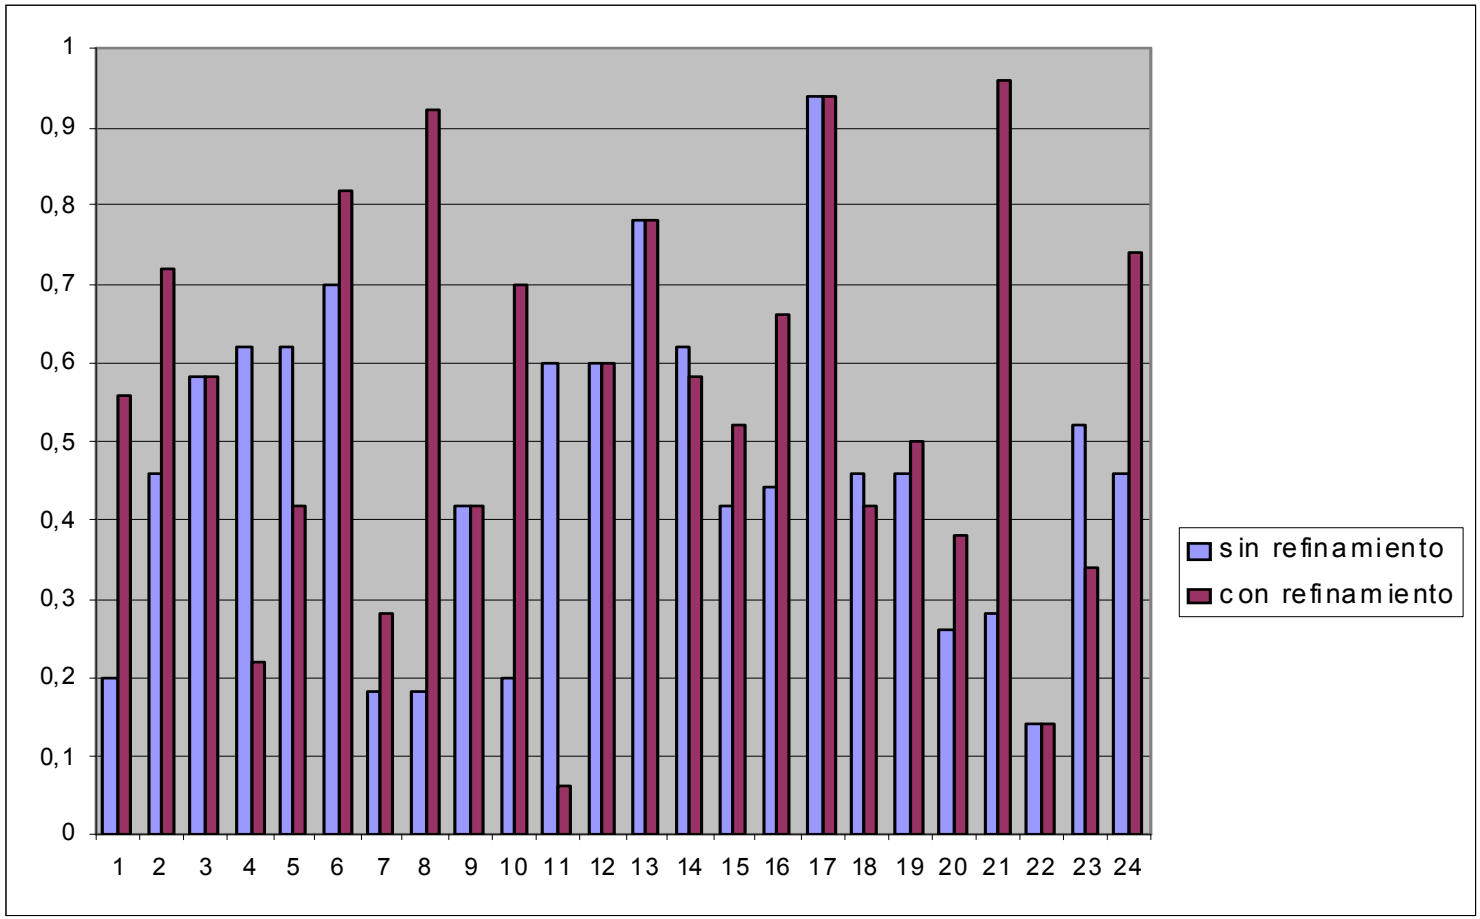

# Resultados de la experimentación

- Promedio cantidad de docs recuperados y la precisión sobre los primeros 50 resultados sin y con RS:

| | Recuperados | Precisión |
|---|---|---|
| Sin refinamiento | 533811,67 | 0,46 |
| Con refinamiento | 651726,67 | 0,55 |
| | 22,09 % | 19,03 % |

- El RS mejora:
  - la cantidad de documentos recuperados en un 22,09 %
  - y la precisión en un 19,03 %.

# Conclusiones

El refinamiento

- Mejora la **cantidad de docs recuperados**
  - Al expandir cada concepto con sinónimos y términos relacionados

- Mejora la **precisión en los primeros n docs**
  - Al permitir al usuario moverse por jerarquías conceptuales

# Conclusiones

- El RS resuelve problemas relacionados con las contingencias:
  - correcto uso de la disyunción y la conjunción,
  - uso correcto de paréntesis,
  - inclusión de sinónimos y variantes de escritura,
  - utilización de términos específicos,
  - uso correcto de la negación y
  - errores de tecleo.

- El refinamiento es semiautomático porque
  un esfuerzo inicial por parte del usuario
  le evita a posteriori la lectura y el descarte de los docs.

# Se está trabajando en

- Búsqueda personalizada de objetos de aprendizaje
  - Utilización de perfiles de usuario.
  - Selección automática de recursos lingüísticos adecuados
  - Expansión multilingual.
  - Utilización de ontologías con axiomas. Incorporar conceptos obtenidos a través de la inferencia.
  - Feedback de relevancia. Mejorar estrategia incorporando conceptos extraídos de docs marcados como relevantes por el usuario.

Muchas gracias….